



Kahramanmaraş Sutcu Imam University

Journal of Engineering Sciences



Geliş Tarihi: 01.11.2020
Kabul Tarihi: 01.03.2021

Received Date : 01.11.2020
Accepted Date : 01.03.2021

DUYGU ANALİZİ VE FİKİR MADENCİLİĞİ UYGULAMALARI ÜZERİNE LİTERATÜR TARAMASI

LITERATURE REVIEW ON SENTIMENT ANALYSIS AND OPINION MINING APPLICATIONS

Hatice Elif EKİM¹ (ORCID: 0000-0001-6623-5847)
Alpaslan Burak İNNER^{1}* (ORCID: 0000-0003-0933-654X)

¹ Kocaeli Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Kocaeli, Türkiye

*Sorumlu Yazar / Corresponding Author: Alpaslan Burak İNNER, binner@kocaeli.edu.tr

ÖZET

Duygu analizi ve fikir madenciliği, kişilerin, bir konu, grup, ürün, marka veya durum ile ilgili görüşlerini belirttiği metinleri, doğal dil işleme, yapay zeka veya istatistik alanlarından uygulamalar yardımıyla analiz ederek anlamlandırma çalışmalarıdır. Son yıllarda, sosyal medya ve kullanıcıların fikir paylaştığı diğer platformların kullanımının artmasıyla saatte terabaytlar seviyesine ulaşan veri miktarı, duygu analizi ve fikir madenciliği konularına verilen önemi artırmıştır.

Bu çalışma kapsamında, duygu analizinde makine öğrenimi yaklaşımları, sözlük tabanlı yaklaşımlar ve hibrit yaklaşım üzerine güncel makaleler incelenerek, makaleler ile ilgili literatür çalışması araştırmacılara sunulmuştur. İncelenen makalelerden, makalenin yayınlanma tarihi, araştırma problemi, yaklaşım, ön işleme ve öz nitelik seçme metotları, sınıflandırma algoritması, model başarı ölçütü, başarı oranı en yüksek algoritma ve başarı oranı, veri kaynağı bilgilerinin yer aldığı bir tablo oluşturulmuştur. Makine öğrenimi tabanlı yöntemlerin sıklıkla tercih edilmesi ve çalışma sayısının diğer yöntemlerden fazla olması sebebiyle, denetimli, denetimsiz, yarı denetimli ve derin öğrenme başlıkları altında ayrı ayrı ele alınmıştır. Çalışma sonucunda, incelenen makaleler ışığında genel bir değerlendirme ile sonuç çıkarılarak çalışma tamamlanmıştır.

Anahtar Kelimeler: Duygu analizi, fikir madenciliği, makine öğrenmesi, derin öğrenme

ABSTRACT

Sentiment analysis and opinion mining are the studies of interpretation by analyzing texts in which people express their opinions about a subject, group, product, brand, or situation with applications with natural language processing, artificial intelligence, or statistics. In recent years, with the increase in the use of social media and other platforms where users share ideas, the amount of data reaching the level of terabytes per hour has increased the importance given to sentiment analysis and opinion mining.

Within the scope of this study, a literature review on current articles and articles on machine learning approaches, lexicon-based approaches, and hybrid approach in sentiment analysis is presented to the researchers. From the articles examined, a table containing the publication date of the article, research problem, approach, preprocessing and feature selection methods, classification algorithm, model success criterion, an algorithm with the highest success rate and success rate, data source information was created. Since machine learning-based methods are frequently preferred and the number of studies is higher than other methods, they are discussed separately under the titles of supervised, unsupervised, semi-supervised, and deep learning. At the end of the study, the study was completed by making a general evaluation in light of the articles examined.

Keywords: Sentiment analysis, opinion mining, machine learning, deep learning

*Sorumlu Yazar / Corresponding Author: Alpaslan Burak İNNER, binner@kocaeli.edu.tr

ToCite: EKİM, H.E. & İNNER, A. B. (2021). DUYGU ANALİZİ VE FİKİR MADENCİLİĞİ YAKLAŞIMLARI VE UYGULAMALARI ÜZERİNE LİTERATÜR ARAŞTIRMASI. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 24(2), 93-114.

GİRİŞ

Sosyal medya, günümüzde milyarlarca kullanıcının çeşitli konularda düşüncelerini, şikayetlerini ve görüşlerini paylaştığı bir platform olarak tüm dünyayı etkisi altına almaktadır. Sosyal medyanın dünya geneline etkisi ile farklı kanallardan her yeni yıl geçmiş yıllara göre çok daha hızlı ve büyük miktarda veri üretilmektedir. Farklı sosyal medya kanalları aracılığı ile (video, görsel, metin, ses vb..) türlü içerikler üretilmesine rağmen içeriklerin büyük çoğunluğu insanların düşüncelerini yazıya dökerek ürettikleri metinlerden oluşmaktadır (Çetin ve Eryiğit, 2018). Sosyal medya paylaşımlarının artması ve kullanıcıların sanal ortamda yorumlarını, düşüncelerini daha fazla paylaşmasıyla veriye verilen önem de artmıştır. Verinin değer kazanması da fikir madenciliği ve duygu analizi çalışmalarını ön plana çıkarmıştır. Fikir madenciliği ve duygu analizi, marka, ürün, hizmet, sosyal ve siyasi çevrede meydana gelen olaylar veya durumlar hakkında, kişilerin, düşüncelerini elektronik ortamda ifade etmesiyle ortaya çıkan verilerin yazılım sistemleri aracılığıyla hızlı olarak analiz edilmesi ve anlamlandırılması işlemidir (Kaynar, Yıldız, Görmez ve Albayrak, 2016).

Fikir madenciliği (Opinion Mining), ilk kez Nasukawa ve Yi'nin (2003) "*Sentiment analysis: Capturing favorability using natural language processing*" adlı çalışmasında "Duygu Analizi (Sentiment Analysis)" biçiminde kullanılmıştır. Fikir madenciliği, uygulama alanlarında farklılıklar olmakla birlikte duygu analizi, fikir çıkarma, duygu madenciliği, etki analizi, öznellik analizi, inceleme madenciliği gibi isimlerle de literatürde kullanıldığı Liu (2012) tarafından belirtilmiştir. Şimdilerde birçok çalışmada fikir madenciliği ve duygu analizi birbiri yerine kullanılsa da iki kavramın kısmen farklı olduğunu söyleyen araştırmacılar da mevcuttur. Duygu analizinde, metinleri analiz ederek ifade ettiği duygu belirlenirken, fikir madenciliğinde, metinde ifade edilen görüş tespit edilir (Esuli ve Sebastiani, 2006).

Fikir Madenciliği ve duygu analizinde kullanılan veri kaynakları, müşteri yorumları, gazete başlıkları (Baccianella, Esuli ve Sebastiani, 2010), blog yorumları (Neviarouskaya, Prendinger ve Ishizuka, 2011) ve sosyal medya paylaşımlarını içerebilmektedir.

Bu makalede, farklı veri kaynakları kullanılarak gerçekleştirilmiş çalışmalar taranarak aralarından seçilen çalışmalar, kullanılan yöntemler ile birlikte ayrı ayrı özetlenmiştir. Makale akışı şu şekilde devam etmektedir; "Duygu Analizi Seviyeleri", "Duygu Analizinde Kullanılan Yöntemler" ve "Duygu Analizi Aşamaları" başlıkları açıklanmıştır. Materyal ve Yöntem bölümünde 2017 yılından 2020 yılına kadar literatürde duygu analizi ve fikir madenciliği alanında yapılmış olan çalışmalar taranmış ve aralarından seçilen çalışmalardan tüm çalışmaları özetleyen bir tablo oluşturulmuştur. "Literatür Taraması" bölümünde incelenen literatür çalışmalarının özetleri araştırmacılara sunulmuştur. Sonuç bölümünde ise incelenen çalışmalardan çıkarılan sonuçlar açıklanarak çalışma tamamlanmıştır.


Duygu Analizi Seviyeleri

Duygu Analizi araştırma seviyeleri bakımından; doküman seviyesi (document level), cümle seviyesi (sentence level) ve görüş seviyesi (aspect level) olmak üzere üç temel başlık altında incelenmektedir. Duygu analizi araştırma seviyeleri Şekil 1'de gösterilmiştir (Medhat, Hassan ve Korashy, 2014).

Doküman seviyesinde duygu analizinde, detaya inilmeden, tüm doküman tek bir fikir olarak ele alınarak, pozitif veya negatif duyguları ifade etme durumuna göre sınıflandırma yapılır (Özyurt ve Akçayol, 2018). Doküman seviyesinde duygu analizi çıktı olarak tek bir sonuç verdiğinden, birden fazla durumda gerçekleştirilen karşılaştırmalar için uygun değildir. İçerik hedefinin tek bir nesne olması durumlarında örneğin, çevrimiçi ürün yorum analizi gibi konularda tercih edilebilir.

Cümle seviyesinde duygu analizi, doküman seviyesinde duygu analizinden çok da farklı olmamakla birlikte, her bir cümlelerin öznel (subjective) veya nesnel (objective) olma durumu kontrol edildikten sonra, cümle öznel ise cümlelerin pozitif veya negatif duygu ifade etme durumuna göre sınıflandırma yapılır (Medhat, Hassan ve Korashy, 2014).

Kişilerin, bir ürün, konu veya kişi hakkında yaptıkları yorumlar, sadece pozitif veya negatif değil aynı zamanda ürün, konu veya kişinin özellikleri hakkında da olabilmektedir. Bu durum karşısında doküman ve cümle seviyesinde duygu analizi yetersiz kalmaktadır. Görüş seviyesinde duygu analizi, varlığı sadece pozitif veya negatif olarak değil tüm yönleriyle ele almayı mümkün kılmaktadır. Doküman ve cümle seviyelerindeki sınıflandırmalarda yorumlar detaylandırılmak zorunda değildir fakat görüş seviyesinde, belirli varlığın belirli özelliklerine ilişkin duygu yönünün belirlenmesi amacı güdüldüğü için yorumlar detaylandırılır (Medhat, Hassan ve Mohamed, 2014). Görüş seviyesinde duygu analizi, farklı çalışmalarda özellik tabanlı duygu analizi (Özyurt ve Akçayol, 2018) veya hedef tabanlı duygu analizi (Çetin ve Eryiğit 2018) olarak da adlandırılmaktadır.



Şekil 1. Duygu Analizi araştırma seviyeleri

Duygu Analizinde Kullanılan Yöntemler

Duygu Analizi alanında gerçekleştirilen çalışmalar, makine öğrenimi yaklaşımları (machine learning approaches), sözlük tabanlı yaklaşımlar (lexicon based approaches) ve hibrit yaklaşım (hybrid approach) olmak üzere üç başlık altında incelenmektedir (Maynard ve Funk, 2011). Duygu analizi yöntemlerinin sınıflandırılması Şekil 2’de kategorilere ayrılarak gösterilmiştir. Makine öğrenmesi tabanlı yaklaşım, sözdizimi (syntax) veya anlamsal (symantic) özellikleri kullanan düzenli bir metin sınıflandırma problemini çözmek için bir model oluşturmakta ve oluşturulan modeli yeni örnekleri sınıflandırmak veya kümelemek için kullanılmaktadır (Medhat, Hassan ve Korashy, 2014).

Makine öğrenimi tabanlı yöntemler, denetimli (supervised), yarı-denetimli (semi-supervised) ve denetimsiz (unsupervised) yöntemler olmak üzere üç ana başlık altında incelenmektedir. Ayrıca hem denetimli hem de denetimsiz öğrenme algoritmalarının kullanılabildiği derin öğrenme (deep learning) algoritmaları son yıllarda popülerliği artan bir makine öğrenimi sınıfıdır. Derin öğrenmenin insan beynini örnek alan, çok katmanlı ve doğrusal olmayan yapısı ile karmaşık problemlerin çözülebilmesi amaçlanmıştır. Derin öğrenmenin diğer makine öğrenimi yöntemlerinden farkı, birden fazla doğrusal olmayan işlem katmanı ile çok yüksek miktarda veri işleme kapasitesine sahip olması ve hesaplama gücü yüksek donanımlara gereksinim duymasındadır (Şeker, Diri ve Balık, 2017).

Denetimli makine öğrenmesi algoritmaları, sınıflandırma (classification) ve regresyon (regression), denetimsiz makine öğrenmesi algoritmaları, kümeleme (clustering) ve boyut azaltma (dimensionality reduction) başlıkları altında incelenmektedir.

Literatürde tercih edilen denetimli makine öğrenimi algoritmalarına; Destek Vektör Makineleri (Support Vector Machine), K-En Yakın Komşu (K-Nearest Neighbours), Karar Ağaçları (Decision Tree), Naive Bayes, Lojistik Regresyon (Logistic Regression), Rastgele Orman (Random Forest), Maksimum Entropi (Maximum Entropy) örnek gösterilirken, denetimsiz makine öğrenmesi algoritmalarına; K-Ortalamalar Kümeleme (K-Means Clustering), Hiyerarşik Kümeleme (Hierarchical Clustering) ve Olasılıksal Kümelemenin (Probabilistic Clustering) de içlerinde bulunduğu kümeleme algoritmaları örnek gösterilmektedir. Yarı denetimli makine öğrenmesi algoritmaları ise denetimli ve denetimsiz öğrenme yöntemlerinin her ikisini de kapsamaktadır.

Literatürde tercih edilen derin öğrenme yöntemleri ise Yapay Sinir Ağı (Artificial Neural Network), Evrişimli Sinir Ağları (Convolutional Neural Network), Tekrarlayan Sinir Ağı (Recurrent Neural Network), Uzun Kısa Süreli Hafıza Ağı (Long Short-Term Memory), Sınırlı Boltzmann Makineleri (Restricted Boltzmann Machines), Derin İnanç Ağları (Deep Belief Networks), Oto-Kodlayıcılar (Autoencoders), Gürültü Giderici Oto-Kodlayıcılar (Denoising Autoencoders)'dir.

Bu alandaki öncü çalışmalara Pang, Lee ve Vaithyanathan (2002) ve Go, Bhayani ve Huang (2009) makine öğrenmesi algoritmalarıyla gerçekleştirdikleri çalışmalar örnek olarak gösterilebilir.

Pang vd. (2002), makine öğrenmesini ilk kez duygu sınıflandırmak amacıyla kullanmışlardır. Çalışmalarında, NB, ME ve SVM sınıflandırıcılarını kullanarak film yorumlarını olumlu/olumsuz sınıflandırmışlardır. Öznitelik seçme için unigram, unigram-bigram ve unigram-POS metodlarını kullanmışlardır. En iyi performansı SVM ile elde etmişlerdir.

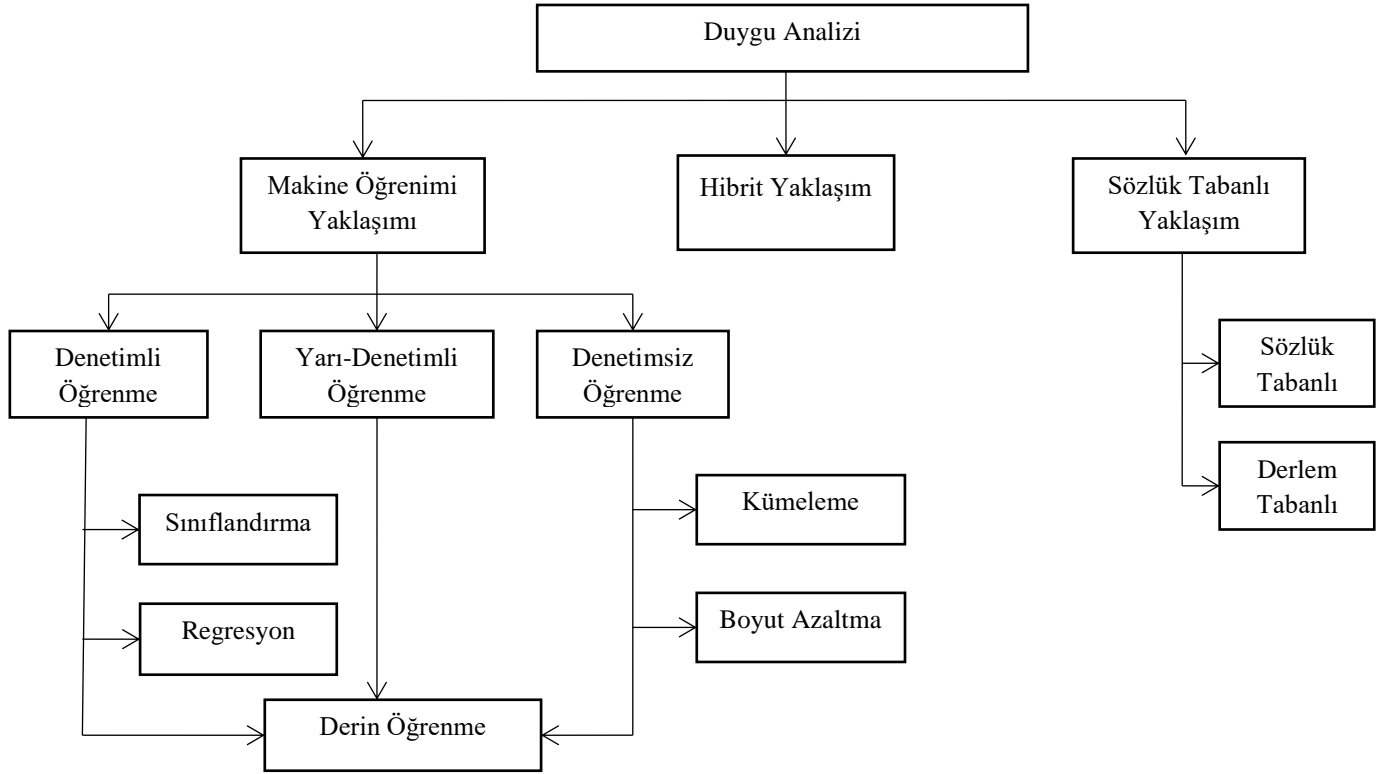
Go vd. (2009) çalışmalarında, 800.000 olumlu, 800.000 olumsuz tweet üzerinde makine öğrenmesi algoritmalarından NB, SVM, ME algoritmalarını kullanarak bigram, unigram öznitelik temsilleri ile duygu analizi yapmayı amaçlamışlardır. En iyi sonuç %83 doğruluk oranıyla ME algoritması ile unigram ve bigramın birlikte kullanılması sonucu elde edilmiştir.

Sözlük tabanlı yöntemler, duygu ifade eden kelime veya kelime gruplarından oluşan sözlükler aracılığı ile duygu analizi yapmayı hedefler. Sözlük tabanlı yöntemlerde, terimlere duyarlılık puanları vermek için mevcut sözlüklerden yararlanılabileceği gibi yeni bir sözlük oluşturulabilir (Turney, 2002). Sözlük tabanlı yöntemler, yüksek ölçeklenebilir olması sebebiyle özellikle bloglar, forumlar ve ürün incelemeleri gibi belirli kalıptaki metinler üzerinde uygulanabilir fakat düzensiz metinler üzerinde, belirli alana özgü kelime ve cümle yapılarında yeterli performansı gösteremedikleri için Twitter duygu analizindeki başarıları yetersiz kalmıştır (Asghar, Ullah, Ahmad, Kundi ve Nawaz, 2014). Sözlük tabanlı yöntemlerde, metinde geçen kelime ve cümlelerin anlamsal yönelimleri baz alınarak bir hesaplama yapılır (Taboada, Brooke, Tofiloski, Voll, Stede, 2011). Sözlük tabanlı yöntemler, derlem tabanlı yaklaşımlar (corpus based approaches) ve sözlük tabanlı yaklaşımlar (dictionary based approaches) olmak üzere iki ana başlık altında incelenmektedir. Sözlük tabanlı yaklaşımda, manuel olarak oluşturulan duygu kelimeleri kümesi, WordNet ve vb. sözlükler kullanılarak kelimelerin eş ve zıt anlamları bulunur ve duygu kelimeleri kümesi genişletilir, yeni bir kelime bulunamadığında arama işlemi sonlandırılır (Hu ve Lui 2004). Derlem tabanlı yaklaşımda ise istatistiksel veya semantik yöntemlerden faydalanılarak görüş kutbu belirlenir.

Sözlük tabanlı fikir madenciliği çalışmalarını destekleyici ilk kapsamlı Türk polarite sözlük kaynağı, WordNet'ten faydalanarak, yaklaşık 15.000 Türkçe kelimenin duygu polaritesini pozitif, negatif ve nötr olmak üzere üç kutuplu gösteren SentiTurkNet duygu analizi sözlüğü Dehkharghani, Saygin, Yanikoglu ve Oflazer (2016) tarafından geliştirilmiştir. SentiTurkNet, birçok sosyal medya duygu analizi çalışmasında kullanılmaktadır (Özsert ve Özgür, 2013).

Hibrit yaklaşım ise, makine öğrenmesi algoritmaları ve sözlük tabanlı yöntemlerin birlikte kullanılması ile gerçekleştirilmektedir (Medhat vd. 2014).

Mukwazvure ve Supreethi (2015), haber yorumları üzerinde, pozitif, negatif ve nötr duygu analizi için hibrit bir yaklaşım önermişlerdir. Çalışmada, web sitesinden indirilen haber yorumları, metin sadeleştirme, durak kelimelerin temizlenmesi, kök alma, ön işleme aşamalarından geçtikten sonra ön işlemeden geçen yorumlar fikir sözlüğü ile sınıflandırılmıştır. Daha sonra sözlük tabanlı yöntemlerden elde edilen sonuçlar, makine öğrenimi algoritmalarını eğitmek için kullanılmıştır. Çalışmada, SVM ve KNN makine öğrenmesi algoritmaları kullanılmış ve SVM'nin KNN'den daha iyi performans gösterdiğini gözlemlemişlerdir.



Şekil 2. Duygu Analizi yöntemleri

Duygu Analizi Aşamaları

Literatürde, sosyal medya paylaşımlarında yapılan duygu analizi çalışmalarında belirgin özelliklerin tespit edilebilmesi ve sınıflandırıcının eğitilebilmesi için verinin farklı aşamalardan geçmesi gerekmektedir. Bu aşamalar; ön işleme, öznelik seçme ve algoritmik işlemler ile modelin eğitilmesidir. Model eğitimi tamamlandıktan sonra elde edilen başarı oranları değerlendirilmektedir. Duygu analizi aşamaları Şekil 3’de gösterilmiştir.



Şekil 3. Duygu Analizi aşamaları

Veri kümesi oluşturulduktan sonra ilk aşama olarak metnin sayısallaştırılmasını kolaylaştırmak için veri ön işleme adımları uygulanmaktadır. Literatürde farklı metinler üzerinde yapılan çalışmalarda tercih edilen ön işleme metotları; metin sadeleştirme (normalization), yazım denetimi (deasciifier), durak kelimelerin temizlenmesi (stop words), retweet ve tekrar eden mesajların elenmesi, kök alma (stemming), dizgi parçalama, kelime bölütleyici (tokenization), morfolojik çözümleyici (morphological analyzer), morfolojik belirsizlik giderici (morphological disambiguator), bağıllık ayrıştırıcısı (dependency parser) şeklindedir. Şekil 4’de veri ön işleme metotları altında gerçekleştirilen işlem adımlarıyla listelenmiştir (Agarwal, Xie, Vovsha, Rambow ve Passonneau, 2011), (Çoban, Özyer ve Özyer, 2015).

Metin sadeleştirme

- Büyük harflerin küçük harflere dönüştürülmesi
- Noktalama işaretlerinin kaldırılması
- Sayısal ifadelerin kaldırılması
- URL bilgilerinin temizlenmesi
- Tekrarlanan harflerin çıkarılması
- Harf olmayan her türlü karakterin temizlenmesi (Hashtag (#) ve kullanıcı adı gibi @ ile başlayan kelimelerin temizlenmesi)

Yazım denetimi

- Yanlış yazılmış kelimelerin düzeltilmesi

Durak kelimelerin temizlenmesi

- Emojilerin temizlenmesi
- Kısaltmaların temizlenmesi
- Alakasız kelimelerin temizlenmesi

Retweet ve tekrar eden mesajların elenmesi

Kök alma

Dizgi parçalama

Kelime bölütleyici

- İki karakterden daha kısa ifadelerin temizlenmesi

Morfolojik çözümleyici

Morfolojik belirsizlik giderici

Bağlılık ayrıştırıcısı

Şekil 4. Veri ön işleme metotları

İkinci aşama olarak veri öznitelik seçme adımları uygulanmaktadır. Veri setini en iyi şekilde temsil eden özniteliklerin belirlenmesi, kelimenin sözlükteki doğru halinin tespit edilmesi, önemsiz kelimelerin kaldırılması başka bir ifadeyle veri setinde ayırt edici özelliği yüksek olan en anlamlı özniteliklerin belirlenmesidir. Literatürde tercih edilen öznitelik seçme yöntemleri; N-gram, Konuşma Bölümü Etiketleme (Part of Speech) (Pang vd., 2002), Ki-kare (Chi-squared) (Turkmen ve Cemgil, 2014), Bilgi Niteliği Çatısı (Information Quality Framework) (Chen ve Tseng, 2011), Kelime Torbası (Bag of Words) (Mikolov, Chen, Corrado ve Dean, 2013), Dağıtık Kelime Torbası (Distributed Bag of Words), Dağıtılmış Bellek (Distributed Memory), Skip-gram ve CBOW modellerini kullanan tahmin tabanlı Word2vec (Mikolov, Sutskever, Chen, Corrado ve Dean, 2013), FastText (Bojanowski, Grave, Joulin ve Mikolov, 2017), GloVe (Global vectors for word representation) (Pennington, Socher ve Manning, 2014), Bilgi Kazanımı (Information Gain), Sorgu Genişletme Sıralaması, Emoticons, Synonyms, Lemmatization, Karınca Kolonisi Optimizasyonu, Kelime Gömme (Word Embedding), Terim Frekansı (Term Frequency) ve Ters doküman Frekansı (Inverse Document Frequency) şeklindedir.

Üçüncü aşama olarak makine öğrenimi yaklaşımları, sözlük tabanlı yaklaşımlar veya hibrit yaklaşımdan uygun olan seçilerek, sınıflandırma veya kümeleme işlemleri gerçekleştirilerek algoritmaların başarı oranları tespit edilmektedir.

Son aşama olarak da, elde edilen başarı oranları karşılaştırılarak işlem yapılan veri seti için en başarılı algoritma bulunur.

MATERYAL VE YÖNTEM

2017-2020 yılları arasındaki fikir madenciliği çalışmaları, yayınlanma senesi, araştırma problemi, yaklaşım, ön işleme ve öznelik seçme metodları, sınıflandırma algoritması, kullanılan algoritmalar/başarı oranları ve veri kaynağı başlıkları altında incelenmiştir. İncelenen çalışmalar neticesinde kullanılan algoritmalar ve başarı oranları tablo haline getirilerek Tablo 1’de gösterilmiştir. İlk sütunda, araştırmacı veya araştırmacıların bilgisi ve çalışmanın yayınlanma tarihi, ikinci sütunda, çalışmada ele alınan araştırma problemi gösterilmiştir. Üçüncü sütunda, çalışmada tercih edilen yaklaşımlar, Makine Öğrenimi, Sözlük Tabanlı ve Hibrit olarak ele alınmıştır. Dördüncü sütunda, çalışmada tercih edilen ön işleme ve öznelik seçme metodları belirtilmiştir. Beşinci sütunda, çalışmada kullanılan sınıflandırma algoritmaları, Karar Ağaçları (DT), Çok Katmanlı Algılayıcı (MLP), Destek Vektör Makinesi (SVM), Lojistik Regresyon (LR), Multinomial Lojistik Regresyon (MLR), Naive Bayes (NB), Gaussian Naive Bayes (GNB), K-En Yakın Komşu (KNN), J48, Maksimum Entropi (ME), Rastgele Orman (RF), Torbalama (Bagging), Yapay Sinir Ağları (ANN), K-ortalama (K-means), Evrişimli Sinir Ağları (CNN), Uzun Kısa Süreli Hafıza Ağı (LSTM), AdaBoost (AB), Ekstrem Gradyan Artırma (XGB), Tekrarlayan Sinir Ağı (RNN), Bulanık C-Ortalamalar (FCM), Olasılıksal Bulanık C-Ortalamalar (PFCM) olarak gösterilmiştir. Altıncı sütunda, model değerlendirilirken temel alınan ölçüt; Doğruluk (Accuracy), F-ölçütü (F-score), Geri çağırma (Recall), Hassasiyet (Precision), ROC eğrisi altında kalan alan (AUC) cinsinden en başarılı algoritma ve algoritmanın başarı oranı gösterilmiştir. Yedinci sütunda, üzerinde çalışılan veri kaynağı araştırmacılara sunulmuştur.

Tablo 1. Makale Özetleri

Referans Numarası / Yıl	Araştırma Problemi	Yaklaşım	Ön İşleme ve Öznelik Seçme Metodları	Sınıflandırma Algoritması	Değerlendirme Ölçütü- En Başarılı Algoritma-Başarı Oranı	Veri Kaynağı
Cliche (2017)	Twitter veri seti üzerinde derin öğrenme algoritmalarıyla duygu analizi çalışması gerçekleştirmek.	Makine Öğrenimi	Ön İşleme Durak kelimelerin temizlenmesi, metin sadeleştirme Öznelik Seçme Word2vec, FastText, GloVe	CNN, LSTM	Doğruluk - CNN + LSTM - %65.8 F-ölçütü - CNN + LSTM - %68.5 Geri çağırma - CNN + LSTM - %68.1	Twitter
Hassan ve Mahmood (2017)	IMDB ve SSTb veri kümeleri üzerinde derin öğrenme ve denetimsiz öğrenme yöntemleri kullanarak karşılaştırmalı duygu analizi çalışması gerçekleştirmek.	Makine Öğrenimi	Öznelik Seçme Word2vec	CNN+ LSTM (ConvLstm)	SSTb veri kümesi - Doğruluk - Word2vec+ ConvLstm- %88.3	IMDB ve SSTb
Kaynar, Aydın ve Görmez (2017)	IMDB kullanıcı yorumlarından elde edilen veri seti üzerinde derin öğrenme tabanlı boyut indirme teknikleri ve literatürde tercih edilen diğer teknikler karşılaştırılarak duygu analizi çalışması gerçekleştirmek.	Makine Öğrenimi	Ön İşleme Metin sadeleştirme, durak kelimelerin temizlenmesi Öznelik Seçme TF-IDF	SVM, ANN	Doğruluk - TF-IDF+ DAE+ANN- %81.6 Hassasiyet - TF-IDF+ DAE+ANN- %83.2 Doğruluk - TF-IDF+ AE+ANN- %81.6 Hassasiyet - TF-IDF+ AE+ANN-	IMDB

					%83.5	
Ding, Li, Zhao ve Cheng (2017)	Ly.com'dan alınan kullanıcı yorumları veri seti üzerinde Çin duygu sözlüğüne dayanan, yorumlara göre turisti otomatik puanlayan bir duygu analiz sistemi tasarlamak.	Sözlük Tabanlı	Ön İşleme Metin sadeleştirme, kelime bölütleyici			Ly.com (Çin Seyahat rezervasyon sitesi)
Onan (2017)	Türkçe Twitter paylaşımları üzerinde makine öğrenmesi algoritmaları ile duygu analizi çalışması gerçekleştirmek.	Makine Öğrenimi	Ön İşleme Metin sadeleştirme, durak kelimelerin temizlenmesi, retweet ve tekrar eden mesajların elenmesi Öznitelik Seçme 1-gram, 2-gram, 3-gram	NB, SVM, LR	Doğruluk - 1-gram & 2-gram+ NB- %77.78 F-ölçütü - 1-gram & 2-gram+ NB- %79 AUC 1-gram & 2-gram+ NB- %85	Twitter
Hayran ve Sert (2017)	Türkçe Twitter paylaşımları üzerinde, öznitelik uzayını düşürmek amacıyla füzyon ve kelime gömme tekniklerine dayalı duygu analizi çalışması gerçekleştirmek.	Makine Öğrenimi	Ön İşleme Metin sadeleştirme, yazım denetimi, retweet ve tekrar eden mesajların elenmesi Öznitelik Seçme Word2vec (CBOW ve Skip-Gram)	SVM	Doğruluk - Varyans + Ortalama + Toplam (Dvot) Word2vec + SVM- %80.05	Twitter
Pervan ve Keleş (2017)	E-ticaret sitelerinden toplanan müşteri yorumları üzerinde duygu analizi çalışması gerçekleştirmek.	Makine Öğrenimi	Ön İşleme Metin sadeleştirme, durak kelime temizleme Öznitelik Seçme Word2vec	RF	Doğruluk - Word2vec + RF- %84.23	E-ticaret siteleri müşteri yorumları
Parlar, Saraç ve Özel (2017)	Duygu analizi için kullanılan öznitelik çıkarma yöntemlerinin, Türkçe Twitter verileri üzerindeki performansını değerlendirmek.	Makine Öğrenimi	Ön İşleme Metin sadeleştirme, yazım denetimi, durak kelime çıkarma Öznitelik Çıkarma Ki-kare, Sorgu Genişletme Sıralaması, Bilgi Kazanımı Karınca Kolonisi Optimizasyonu	ME	100 Nitelik F-ölçütü - ME + χ^2 - %69.72 250 Nitelik F-ölçütü - ME + KKO- %78.88 500 Nitelik F-ölçütü - ME + QER- %77.93	Twitter
Rane ve Kumar (2018)	ABD Havayolu şirketi hakkında yazılan tweetlerden oluşan veri kümesi üzerinde yedi farklı sınıflandırma algoritması ile duygu	Makine Öğrenimi	Ön İşleme Metin sadeleştirme, durak kelime çıkarma, kök alma Öznitelik	DT, RF, SVM, NB AB, LR, KNN	Hassasiyet - Doc2Vec+ RF- %85.6	Twitter

	analizi çalışması gerçekleştirmek.		Seçme Doc2Vec			
Salur ve Aydın (2018)	Twitter mesajları üzerinde makine öğrenimi algoritmaları ve derin öğrenme algoritması olan CNN ile duygu analizi çalışması gerçekleştirmek ve paket boyutunun sınıflandırmaya etkisini incelemek.	Makine Öğrenimi	Ön İşleme Metin sadeleştirme Öznitelik Seçme Manuel öznitelik seçimi	CNN, KNN, LD, DT, SVM, LR	Doğruluk - CNN- %71.49	Twitter
Kurniawati ve Pardede (2018)	Batı Java Valisi'nin seçimi ile ilgili tweetler üzerinde Bilgi Kazanımı ve Parçacık Sürü Optimizasyonu öznitelik çıkarma yöntemlerini hibrit olarak kullanarak duyarlılık analizi sistemi geliştirmek.	Makine Öğrenimi	Ön İşleme Kelime bölütleyici Öznitelik Seçme IG, PSO etiketleme	SVM	Doğruluk - IG+ PSO etiketleme+ SVM- %94.8	Twitter
Desai (2018)	Film tweetleri üzerinden denetimli ve denetimsiz öğrenme algoritmalarını bir arada kullanarak duygu analizi çalışması gerçekleştirmek.	Makine Öğrenimi	Ön İşleme Metin sadeleştirme, yazım denetimi Öznitelik Seçme Emoticon, Synonyms, 3-gram	SVM, NB, FCM, PFCM	Doğruluk - PFCM+ 3-gram+ SVM- %91.67	Twitter
Naz, Sharan ve Malik (2018)	Ağırlıklılandırmanın sınıflandırıcı doğruluğu üzerindeki etkisini gözlemlemek için Twitter veri seti üzerinde duygu analizi çalışması gerçekleştirmek.	Makine Öğrenimi	Ön İşleme Durak kelimelerin temizlenmesi Öznitelik Seçme Tf, Tf-idf, Binary, 1-gram, 2-gram, 3-gram	SVM	Doğruluk - 1-gram+ SCV+ Binary+ SVM- %81.0	Twitter (SemEval 2016)
Yüksel ve Tan (2018)	Foursquare kullanıcı yorumları üzerinde duygu analizi yöntemleri ile ikili ve üçlü sınıflandırma yaparak karar destek sistemi geliştirmek.	Makine Öğrenimi	Ön İşleme Yazım denetimi, retweet ve tekrar eden mesajların elenmesi	El ile etiketleme, SBKA, NB, Text Analysis API	İkili Sınıflandırma Doğruluk- SBKA- %84,49 Üçlü Sınıflandırma Doğruluk- SBKA- %81,97	Foursquare
Çiftçi ve Apaydın (2018)	Hepsiburada ve Beyazperde verileri üzerinde geleneksel makine öğrenimi algoritmaları ve derin öğrenme RNN mimarisini olan LSTM ile karşılaştırmalı duygu analizi çalışması gerçekleştirmek.	Makine Öğrenimi	Ön İşleme Metin sadeleştirme, yazım denetimi, durak kelime çıkarma Öznitelik Seçme TF-IDF	NB, LR, LSTM	Doğruluk Kelime Temsilleri+ LSTM- %82.9 Geri Çağırma - Kelime Temsilleri+ LSTM- %83 Hassasiyet -	Hepsiburada Beyazperde

					Kelime Temsilleri+ LSTM- %86	
Çoban ve Özyer (2018)	Türkçe Twitter paylaşımlarından oluşan Twitter veri kümesi üzerinde, word2vec ve kümeleme tabanlı metin temsili yöntemlerinin Twitter duygu analizine uygulanabilirliğini incelemek.	Makine Öğrenimi	Ön işleme Kelime bölütleyici Öznitelik Seçme TF-IDF, W2VC, BoW, CBoW, Skip-gram	SVM	Doğruluk -TF-IDF+ BoW+ SVM %72.21 Kesinlik-Hassasiyet-F-ölçütü TF-IDF+ BoW+ SVM %72	Twitter
John, John ve Sheik (2019)	Sentiment140.com'dan alınan Tweet verileri üzerinde sözlük tabanlı duygu analiz çalışması gerçekleştirmek.	Sözlük Tabanlı	Ön İşleme Metin sadeleştirme, durak kelimelerin temizlenmesi, yazım denetimi, kök alma	SentiWordNet Classification, Domain Specification Classification, Hybrid Lexicon Classification	Doğruluk -SentiWordNet Classification- %79.80	Twitter
Lee, Gan, Tan ve Abdullah (2019)	IMDB veri kümesi üzerinde, yarı denetimli derin sinir ağı ve denetimli derin sinir ağı performanslarını, karşılaştırmak.	Makine Öğrenimi		Derin Sinir Ağı	Doğruluk -Yarı Denetimli Derin Sinir Ağı- %82	IMDB
Ray ve Chakrabarti (2019)	Twitter, film ve restoran inceleme verileri üzerinde, hedef tabanlı duygu analizi için derin öğrenme ve kural tabanlı yöntemleri birlikte kullanarak duygu analiz çalışması gerçekleştirmek.	Makine Öğrenimi	Ön İşleme Metin sadeleştirme, durak kelimelerin temizlenmesi Öznitelik Seçme Skip-Gram, POS etiketleme	CNN, Kural Tabanlı Yaklaşım	Doğruluk -Skip-Gram+ CNN+ Kural Tabanlı Yaklaşım- %87	Twitter
Kamiş ve Goularas (2019)	Twitter verileri üzerinde, derin öğrenme yöntemlerinin performanslarını karşılaştırarak duygu analizi çalışması gerçekleştirmek.	Makine Öğrenimi	Ön İşleme Metin sadeleştirme, durak kelimelerin temizlenmesi Öznitelik Seçme Word2Vec, GloVe	CNN, LSTM	Doğruluk -Çoklu CNN & LSTM+ GloVe- %59	Twitter
Rumelli, Akkuş, Kart ve Işık (2019)	Hepsiburada.com'da kullanıcıların yaptığı ürün yorumları ve değerlendirmeleri üzerinde makine öğrenimi ve sözlük tabanlı yaklaşımları bir arada kullanarak duygu analiz modeli geliştirmek.	Hibrit	Ön İşleme Metin sadeleştirme Öznitelik Seçme Booster Words, 1-gram, 2-gram	NB, RF, SVM, KNN	Doğruluk -KNN- %73.8	Hepsiburada.com kullanıcı yorumları
Al-Hadhrami, Al-Fassam ve Benhidour (2019)	Twitter verileri üzerinde denetimli ve denimsiz makine öğrenimi algoritmalarını	Makine Öğrenimi	Ön İşleme Metin sadeleştirme Öznitelik Seçme	SVM, RF, K-means	Geri Çağırma -SVM + 1-gram- %76.93	Twitter

	karşılaştırmak.		1-gram, 2-gram			
Çelik ve Aslan (2019)	Belirlenen markaların Facebook yorumları üzerinde makine öğrenimi tekniklerinden faydalanarak yorum yapanların cinsiyetlerini tahmin etmek.	Makine Öğrenimi	Ön İşleme Metin sadeleştirme, durak kelimelerin temizlenmesi	ANN, DT, SVM, NB, LR, KNN, XGB	Doğruluk-LR- %74,13	Facebook
Bilgin ve Şentürk (2019)	Türkçe ve İngilizce Twitter verileri üzerinde yarı denetimli ve denetimli öğrenme yöntemlerini karşılaştırılarak duygu analizi çalışması gerçekleştirilmek.	Makine Öğrenimi	Ön İşleme Metin sadeleştirme, durak kelime çıkarma Öznelik Seçme DM, DBoW, Doc2Vec	Geliştirilen yarı denetimli algoritma, SVM	F-ölçütü- Geliştirilen yarı denetimli algoritma +DBoW- %44.67 (TR) %58.63 (EN)	Twitter
El Rahman, Alotaibi ve Alshehri (2019)	McDonalds ve KFC ile ilgili Twitter verileri üzerinde, denetimli ve denetimsiz makine öğrenmesi algoritmalarını birlikte kullanarak farklı bir model ile duygu analizi çalışması gerçekleştirilmek.	Makine Öğrenimi	Ön İşleme Metin sadeleştirme, tokenization	NB, SVM, ME, DT, RF, Bagging	McDonald's veri seti Doğruluk-ME- %74 KFC veri seti Doğruluk-ME- %78	Twitter
Yurtalan, Koyuncu ve Turhan (2019)	Türkçe için sözlük temelli kutup belirleme ve hesaplama yöntemi geliştirilerek Türkçe Twitter paylaşımları üzerinde model başarısını ölçmek.	Sözlük Tabanlı	Ön İşleme Metin sadeleştirme, yazım denetimi, tokenization Öznelik Seçme POS, 2-gram 3-gram		Doğruluk- %88.2	Twitter
Erşahin, Aktaş, Kılınc ve Erşahin (2019)	Twitter, otel ve film veri setleri üzerinde, sözlük tabanlı yöntemleri ve makine öğrenimi yaklaşımını birleştirerek duygu analizi çalışması gerçekleştirilmek.	Hibrit	Ön İşleme Metin sadeleştirme Öznelik Seçme Lemmatization	NB, SVM, J48, eSTN	Otel veri seti Doğruluk-eSTN+SVM- %91.96 Film veri seti Doğruluk-eSTN+SVM- %86.31 Twitter veri seti Doğruluk-eSTN+NB- %83.37	Twitter Otel Film
Ayvaz, Yıldırım ve Salman (2019)	Türkçe Twitter paylaşımlarında yapılan duygu analizi çalışmaları için yeni ve kapsamlı bir duygu kütüphanesi geliştirmek.	Sözlük Tabanlı	Ön İşleme Metin sadeleştirme		Yaz-nötr Sonbahar-olumlu İlkbahar-olumlu Kış-olumsuz	Twitter
Osmanoğlu, Atak, Çağlar, Kayhan ve	eCampus sisteminden toplanan geri bildirimlerin analiz edilerek, ders	Makine Öğrenimi	Ön İşleme Metin sadeleştirme, yazım denetimi,	DT, MLP, XGB, SVM, MLR, GNB, KNN	Doğruluk-MLR- %77,5	Anadolu Üniversitesi eCampus


Can (2020)	materyallerinin kişiler üzerindeki etkisinin pozitif, negatif veya nötr olarak sınıflandırılması.		durak kelime çıkarma			
------------	---	--	----------------------	--	--	--

İncelenen makalelerde tercih edilen yöntemlerin grafik gösterimi Şekil 5’te verilmiştir. Duygu analizi yöntemlerinin tercih edilme oranlarına bakıldığında zaman, makine öğrenimi tabanlı yöntemlerin yüksek oranda tercih edildiği görülmektedir. Makine öğrenimi tabanlı yöntemlerin başlıca tercih edilme nedenleri arasında; yüksek başarı oranları, eğitim algoritmalarının kolay gerçekleştirilebilir olması ve yüksek ölçeklenebilirlik gösterilebilir. Sözlük tabanlı yöntemlerde etiketli veriye ihtiyaç duyulmamasına rağmen daha az tercih edilme sebepleri arasında duygu terimleri sözlüğüne ihtiyaç duyulması, başarı oranlarının daha düşük olması, dolaylı olarak ifade edilen duygu kutuplarını ifade etmede başarısız olması gösterilebilir. Makine öğrenimi tabanlı geleneksel yöntemlerden çoğunlukla, SVM, NB, RF ve ME sınıflandırma algoritmaları tercih edilirken, derin öğrenme tabanlı yöntemlerden CNN ve LSTM sıklıkla tercih edilmektedir. Çalışmalar incelendiğinde bu algoritmaların tercih edilmesindeki başlıca sebepler arasında, algoritmaların tek sınıflı çok sınıflı fark etmeksizin farklı problemlere uygulanabilmesi, algoritmaların uygulama kolaylığı, farklı problemlerde yüksek doğruluk oranları elde edilmesi gösterilebilir.

Çalışmalar incelendiğinde, ilk çalışmalarda gerçekleştirilen olumlu/olumsuz sınıflandırma, analiz edilmesi gereken konuya göre şekillenerek problemler ikiden fazla sınıflandırma başlığı altında veya Çelik ve Aslan (2019) çalışmalarında olduğu gibi paylaşım yapanların cinsiyetini tahmin etmeye yönelik gerçekleştirilmeye başlanmıştır. İkili sınıflandırma probleminde kullanılan SVM, NB, LR, CNN, LSTM gibi algoritmalar ihtiyaç doğrultusunda çok sınıflı sınıflandırma problemine uygulanabilmektedir, bu da çok sınıflı sınıflandırma probleminin gelişmesine katkı sağlamaktadır.

Ayrıca literatür çalışmalarının veri kaynağına bakıldığında çalışmaların büyük çoğunluğu Twitter, Facebook, Foursquare gibi sosyal medya verileri üzerinde gerçekleştirilmiştir. Bu da sosyal medyanın duygu analizi için uygun veri kaynaklarından biri olduğunu açıkça göstermektedir.

■ Makine Öğrenmesi Tabanlı ■ Sözlük Tabanlı ■ Hibrit Tabanlı



Şekil 5. İncelenen makalelerde tercih edilen yöntemler grafik gösterimi

LİTERATÜR TARAMASI

Bu makalede, sosyal ağlar, internet siteleri ve çeşitli bloglardan elde edilen veri setleri üzerinde gerçekleştirilen 30 makale Tablo 1’ de özetlenmiştir. Literatür taraması bölümünde, Tablo 1’de belirtilen yaklaşım başlığına göre incelenen çalışmalar sınıflandırılarak açıklanmıştır.

DUYGU ANALİZİNDE MAKİNE ÖĞRENİMİ YAKLAŞIMI LİTERATÜR ÇALIŞMALARI

Makine öğrenimi tabanlı duygu analizi çalışmalarında, denetimli öğrenme algoritmaları kullanılacaksa, metinler etiketlenir, denimsiz öğrenme algoritmaları kullanılacaksa etiketleme yapılmadan sonraki aşamaya geçilir. İkinci

aşamada, gereksiz bilgileri barındıran bozuk metinler çeşitli metin madenciliği yöntemleri ile uygun ön işleme aşamalarından geçirilerek temizlenir. Üçüncü aşamadan sınıflandırmaya veya kümelemeye elverişli hale getirmek üzere öznitelik vektör uzay modelleri oluşturulur. Dördüncü aşamada, denetimli öğrenme için işlenmiş veri, tercih edilen oranlarda eğitim, test, doğrulama gibi alt parçalara ayrılır ve son aşamada, model, veri setleri ile eğitildikten sonra test verileri aracılığıyla duygu durumu tahmini yapılır.

Bir çalışmada sadece denetimli öğrenme yöntemleri veya sadece denetimsiz öğrenme yöntemleri tercih edilebileceği gibi Al-Hadhrami vd. (2019) çalışmalarında tercih edilen hem denetimli hem denetimsiz yöntemler kullanılarak karşılaştırmalı sonuçlar sunulabilmekte veya El Rahman vd. (2019) çalışmalarında olduğu gibi her ikisi birlikte kullanılarak yeni bir model geliştirilebilmektedir.

Al-Hadhrami vd. (2019) çalışmalarında, İngilizce tweetler üzerinde duygu analizi için kullanılan, denetimli makine öğrenmesi algoritmalarından SVM ve RF, denetimsiz makine öğrenmesi algoritmalarından K-means kümeleme algoritmalarının karşılaştırması yapılmıştır. Öznitelik seçimi için unigram ve bigram yaklaşımların özellikleri kullanılmıştır. Çalışma sonucunda, SVM'nin diğer yaklaşımlardan daha iyi performans gösterdiği görülmüştür.

El Rahman vd. (2019) çalışmalarında, iki restoran (McDonalds ve KFC) ile ilgili tweet datalarını toplayarak, hangi restoranın daha popüler olduğunu bulmak, duygu analizi (olumlu/olumsuz/nötr) yapabilmek için denetimli ve denetimsiz makine öğrenmesi algoritmalarını birlikte kullanarak farklı bir model geliştirmişlerdir. Ön işleme adımlarından, metin sadeleştirme ve durak kelimelerin temizlenmesi işlemleri yapılmıştır. Tweet'leri, olumlu, olumsuz, nötr sınıflandırmak için sözlük tabanlı bir model kullanılmıştır. Çalışmada kullanılan denetimli öğrenme algoritmaları, NB, SVM, ME, DT, RF ve bagging'dir. Indicator olarak kullanılan çapraz doğrulama metodu ile iki veri seti için de en yüksek başarı yüzdesi (McDonalds %74, KFC %78) ME ile elde edilmiştir.

Denetimli Öğrenme (Supervised Learning)

Denetimli öğrenmede, bir grup girdi değerine karşılık gelen, hedef değerleri verilerek oluşturulan modelin, girdi-hedef arası ilişkiyi öğrenerek, hedef değerlere en yakın çıktılarının üretilmesi amaçlanmaktadır (Atalay ve Çelik, 2017). Sistem, önceden verilen eğitim setleri ve bunların eğitim kümesindekilerle benzerlikleri karşılaştırarak tahminde bulunur (Ian ve Eibe, 2005). Denetimli öğrenmede amaç, en düşük hata payı ile en doğru tahmini yapabilmektir. Katman sayısının artması ve donanımın gelişmesiyle doğru orantılı olarak öğrenme algoritmaları da düşük hata payı ile daha doğru tahminler yapabilmektedir.

Denetimli öğrenme algoritmaları kullanılarak gerçekleştirilen güncel çalışmalara bu bölümde yer verilmektedir.

Onan (2017) çalışmasında, makine öğrenmesi algoritmalarından, NB, SVM ve LR ile Türkçe Twitter mesajlarında duygu sınıflandırma işlemi gerçekleştirmiştir. Metin temsili için 1-gram, 2-gram ve 3-gram öznitelik seçme yöntemlerinden yararlanılmıştır. Çalışma sonucunda, 1-gram ve 2-gram öznitelik setlerinin birleştirilmesiyle oluşturulan öznitelik seti ve NB sınıflandırma algoritması ile en yüksek doğruluk oranı %77.78 elde edilmiştir.

Hayran ve Sert (2017) çalışmalarında, Türkçe tweetlerin olumlu/olumsuz sınıflandırılması için, öznitelik temsili ve füzyonuna dayalı bir yaklaşım önermişlerdir. Öznitelik temsili için kelime gömme ve sınıflandırma için SVM kullanılmıştır. Öğrenme işleminin gerçekleştirildiği yeni öznitelik füzyonu, kelime gömme temsillerinden elde edilen istatistiksel göstergeler farklı kombinasyonlar ile kaynaştırılmıştır. Çalışma sonucunda, önerilen yöntemin tweet temsili boyutunu önemli ölçüde azalttığı ve duygu sınıflandırmasının doğruluğunu iyileştirdiği gösterilmiştir. En yüksek sınıflandırma doğruluğu %80.05 oranında Dvot füzyon tekniği ile elde edilmiştir.

Pervan ve Keleş (2017) çalışmalarında, e-ticaret sitelerinden toplanan müşteri yorumları üzerinde kelime modellerini Word2vec algoritması ile oluşturarak, RF sınıflandırma algoritması ile ürün inceleme verileri üzerinde ikili (pozitif/negatif) sınıflandırma yapmışlardır. Veri ön işleme adımlarından, metin sadeleştirme, kelime bölütleyici ve yazım denetimi işlemleri, öznitelik seçme işlemi için Word2vec model uygulanmıştır. Çalışmadan, % 84.23'lük bir doğruluk oranı elde edilmiştir.

Parlar vd. (2017) çalışmalarında, duygu analizi için kullanılan öznitelik seçim yöntemlerinin, Türkçe Twitter paylaşımlarından oluşan veri seti üzerindeki performansını değerlendirmek amacıyla, Türkçe tweetlerden oluşan

veri kümesi üzerinde, Ki-kare, Sorgu Genişletme Sıralaması, Bilgi Kazanımı ve Karınca Kolonisi Optimizasyonu olmak üzere dört farklı öznitelik seçme yönteminin performansını, ME sınıflandırma algoritması kullanılarak karşılaştırmışlardır. Çalışma sonucunda, Karınca Kolonisi Optimizasyonu ve Sorgu Genişletme Sıralaması yöntemlerinin başarı oranlarının, Ki-kare ve bilgi kazanımı gibi geleneksel yöntemlerden daha yüksek olduğu gözlemlenmiştir.

Kurniawati ve Pardede (2018) çalışmalarında, Batı Java Valisi'nin seçimi ile ilgili tweetler üzerinde duygu analizi gerçekleştirmişlerdir. En uygun öznitelik seçimi için Parçacık Sürü Optimizasyonu (Particle Swarm Optimization) ve Bilgi Kazancı (Information Gain) yöntemlerini ve sınıflandırıcı olarak SVM kullanmışlardır. Çalışma neticesinde, önerilen sistemin %94.80 oranında başarılı olduğu, PSO ve IG yöntemlerinin, SVM ile birlikte çalıştığında, çalışma sonuçlarını iyileştirdiği gözlemlenmiştir.

Naz vd. (2018) çalışmalarında, SemEval 2016 araştırmacıların kullanımına sunulan Twitter veri setini kullanarak, ağırlıklandırmanın sınıflandırıcı doğruluğu üzerindeki etkisini anlamak için üç farklı ağırlık şemasıyla birlikte n-gram özellikleri kullanarak SVM sınıflandırıcısı ile ikili (pozitif/negatif) Twitter duygu analizi gerçekleştirmişlerdir. Ek olarak duygu puan vektörü (SCV) kullanılarak deneyler de yapılmıştır. Çalışmada kullanılan ağırlıklandırma şemaları, terim frekansı (TF), terim frekansı-ters belge frekansı (TF-IDF) ve binary'dir. N-gram özellik setleri, unigram, bigram, trigram ve bu üçünün birleşimi şeklindedir. En başarılı sonuç, unigram özellik seti ve SCV'nin birlikte kullanılmasıyla oluşturulan, binary ağırlıklandırma şemasının kullanıldığı, SVM tabanlı bir sınıflandırıcı (%81) ile elde edilmiştir.

Çoban ve Özyer (2018) çalışmalarında, konuya bağımlı ve konudan bağımsız Türkçe Twitter paylaşımlarından oluşan iki farklı veri kümesi üzerinde, Word2vec ve kümeleme tabanlı metin temsili yöntemlerinin Twitter duygu analizine uygulanabilirliğini incelemiştir. Ön işleme adımlarından metin sadeleştirme, durak kelime temizleme adımları uygulanırken kelime vektörleri oluşturmak için Bow ve skip-gram mimarileri kullanılmıştır. Kümeleme algoritması olarak k-means, sınıflandırma algoritması olarak SVM kullanılmıştır. Çalışma neticesinde, Word2vec, yöntemin nitelik uzayını azalttığı için zaman ve performans açısından avantaj sağladığı fakat doğruluk açısından elde edilen başarı oranının yeterli olmadığı gözlemlenmiştir.

Yüksel ve Tan (2018) çalışmalarında, kişilerin, mekanlar hakkındaki görüşlerini paylaştığı Foursquare platformundaki yorumlara metin madenciliği ve duygu analizi yöntemleri uygulayarak karar destek sistemi geliştirmeyi amaçlamışlardır. Çalışmada, İngilizce için oluşturulan duygu analiz yöntemleri incelenerek Türkçeye özel yeni bir yöntem geliştirilerek iki yöntem birleştirilmiştir. Ön işleme çalışmalarından, metin sadeleştirme, yanlış yazılan kelimeleri düzeltmek amacıyla yazım denetimi ve durak kelime temizleme işlemleri uygulanmıştır. Çalışma için ilk olarak sözlük tabanlı yaklaşım denenmiştir fakat Türkçe metinler üzerinde %100 başarı elde edilemediği için algoritmanın düzenlenmesi gerektiği sonucuna ulaşılmıştır. Duygu analizi için, doğal dil işleme ve metin madenciliği teknikleri ile Sosyal Bilgi Keşfi Algoritması (SBKA) geliştirilmiştir. Çalışmada ikili (olumlu, olumsuz) ve üçlü (olumlu, olumsuz ve nötr) sınıflandırma yapılmıştır, iki sınıflandırmada da en başarılı algoritma SBKA olmuştur.

Çelik ve Aslan (2019) çalışmalarında, ANN, DT, SVM, NB, LR, KNN, XGB makine öğrenmesi tekniklerinden faydalanarak belirlenen markalara yapılan Facebook yorumları üzerinden belirlenen yorumları yapanların cinsiyetlerini tahmin etmeyi amaçlamışlardır. Çalışma bağlamında, yorumcuların cinsiyetleri yorumcuların adına göre etiketlenmiştir. Araştırma sonucunda, makine öğrenimi yöntemlerinden LR ile en yüksek doğruluk (%74.13) oranı elde edilmiştir.

Osmanoğlu vd. (2020), Anadolu Üniversitesi eCampus sisteminden toplanan geri bildirimleri, makine öğrenme teknikleri kullanarak analiz ederek, materyalin kişiler üzerindeki etkisini pozitif, negatif veya nötr olarak sınıflandırarak negatif geri dönüşlü makalelerin geliştirilmesi için fikir vermeyi amaçlamışlardır. Çalışmada, ilk olarak metin ön işleme adımlarından, metnin sadeleştirilmesi, yazım denetimi, durak kelime çıkarma uygulanmıştır. Makine öğrenmesi, denetimli öğrenme tekniklerinden olan; DT, MLP, XGB, SVM, MLR, gaussian NB ve KNN algoritmaları kullanılmıştır. Eğitim için, 6059 adet etiketli veri kullanılmıştır. %77.5 başarı oranıyla LR algoritması en başarılı sınıflandırma algoritması olmuştur.

Yarı Denetimli Öğrenme (Semi-Supervised Learning)

Yarı denetimli öğrenme, uygun sınıflandırıcı modelini geliştirmek için az miktarda etiketli veri ve çok miktarda etiketsiz veriler ile gerçekleştirilmektedir (Osmanoğlu vd., 2020). Yarı denetimli öğrenme, etiketsiz verinin kolay elde edilebildiği, etiketli verinin az olduğu durumlarda tercih edilebilir (Ayvaz vd., 2019). Yarı denetimli öğrenmede, etiketli veri miktarı az olacağı için veri etiketleme işlemi için harcanan çaba ve zaman daha az olacaktır.

Yarı denetimli öğrenme algoritmaları kullanılarak gerçekleştirilen güncel çalışmalara bu bölümde yer verilmektedir.

Bilgin ve Şentürk (2019) çalışmalarında, Türkçe ve İngilizce tweetler üzerinde, DBoW ve DM doküman vektörlerini (Doc2Vec) kullanarak, yarı denetimli ve denetimli öğrenme metodları (SVM) karşılaştırılarak duygu tabanlı sınıflandırma gerçekleştirmişlerdir. Türkçe veri kümesi için özel bir telekom şirketine ait tweetler seçilirken, İngilizce veri kümesi için Amerika'daki altı büyük havayolu şirketi müşterilerinin bir hafta içinde yazdıkları tweetler seçilmiştir. Ön işleme adımlarından, metin sadeleştirme, durak kelimelerin temizlenmesi işlemleri gerçekleştirilmiştir. Çalışma sonucunda, hem Türkçe hem de İngilizce veri kümelerinde, yarı denetimli öğrenme yöntemlerinin, denetimli öğrenme yöntemlerine kıyasla daha başarılı sonuçlar elde ettiği görülmüştür.

Denetimsiz Öğrenme (Unsupervised Learning)

Denetimsiz öğrenme, verinin kaç sınıfa ayrıldığı, girdilere karşılık gelen çıktılar bilinmeden etiketsiz (anlamsız) veriden anlam çıkarma yöntemidir. Veriler, kümelere veya ortak özelliklere bağlı olarak anlamlandırılır. Kümeleme işlemi, denetimsiz öğrenme yöntemidir.

Denetimsiz öğrenme algoritmaları kullanılarak gerçekleştirilen güncel çalışmalara bu bölümde yer verilmektedir.

Desai (2018) çalışmasında, Fuzzy C-Means (FCM) ve Possibilistic Fuzzy C-Means (PFCM) algoritmalarını ayrı ayrı SVM ile birlikte uygulayarak film tweet'lerinde duygu analizi çalışması gerçekleştirmiştir. Tweet ön işleme adımlarından, metin sadeleştirme, durak kelimelerin temizlenmesi ve retweet ve tekrar eden mesajların elenmesi adımları uygulanmıştır. Çalışmada kullanılan denetimli makine öğrenmesi algoritmaları, SVM ve NB, denetimsiz makine öğrenmesi algoritmaları, FCM ve PFCM'dir. Öznitelik seçme metodlarından, emoticons, synonyms ve 3-gram kullanılmıştır. Çalışma sonucunda, SVM + PFCM'nin, SVM + FCM'den daha başarılı sonuç elde ettiği görülmüştür.

Derin Öğrenme (Deep Learning)

Derin öğrenme, aynı anda birçok işlemi yapan, çok katmanlı sinir ağı yapısıyla son yıllarda yapılan çalışmaların arttığı makine öğrenmesi alanıdır. Öğrenme süreci, sonucun başarı oranı belli bir seviyeye ulaşana kadar tekrarlanır. Derin öğrenmenin en önemli özelliği, çok katmanlı mimarisi sayesinde büyük miktarda veriyi işleyebilmesidir. Derin öğrenmede gereken eğitim süresi yüksek olabilir fakat verileri test etmek daha az zaman alır (Chakraborty, Bag ve Bhattacharyya, 2018). Derin öğrenme, bilgisayarla görme, konuşma tanıma ve doğal dil işleme gibi birçok alanda başarı sağlamıştır (Chen ve Zhang, 2018). Son yıllarda veri miktarının artması ve işlem gücü yüksek donanım araçlarının gelişmesiyle, derin öğrenme yöntemlerinin duygu analizinde kullanıldığı çalışmalarda artış görülmektedir.

Derin öğrenme algoritmaları kullanılarak gerçekleştirilen güncel çalışmalara bu bölümde yer verilmektedir.

Cliche (2017) çalışmasında, büyük miktar etiketlenmiş SemEval-2017 Twitter veri seti üzerinde, CNN ve LSTM ağlarını kullanarak duygu sınıflandırıcısı geliştirmiştir. Çalışmada veri ön işleme metodlarından, durak kelimelerin temizlenmesi ve metin sadeleştirme uygulanmıştır. Kelime temsili (word embedding) için etiketsiz veri kümesi kullanılarak üç farklı denetimsiz öğrenme algoritması (Word2vec, FastText, GloVe) üzerinde çalışmalar yapılmıştır. Çalışma sonucunda, Word2vec, FastText ve GloVe öznitelik seçim algoritmaları ve CNN, LSTM ağları farklı kombinasyonlarla test edildiğinde, GloVe öznitelik seçme metodu düşük başarı oranı verirken diğer

metotlarla oluşturulan modellerde daha yüksek başarı oranı elde edilmiştir. Ayrıca 10 CNN ve 10 LSTM ağıının birlikte kullanılması ile oluşan topluluk modeli ile yaklaşık %65 doğruluk oranı elde edilmiştir.

Hassan ve Mahmood (2017), iki farklı duygu analizi veri seti (Stanford Large Movie Review Dataset IMDB and Stanford Sentiment Treebank dataset SSTb) üzerinde derin öğrenme ve denetimsiz öğrenme yöntemleri kullanarak, karşılaştırmalı duygu analizi çalışması gerçekleştirmişlerdir. Çalışmada öznelik seçme metodlarından, Word2vec kullanılmıştır. Diğer çalışmalardan farklı olarak, önceden eğitilmiş kelime vektörlerinin üstüne, CNN ve LSTM tekniklerini kullanan bir sinir ağı mimarisi olan ConvLstm'yi geliştirmişlerdir. Gerçekleştirilen modelde LSTM katmanı, ayrıntılı yerel bilgi kaybını azaltmak ve uzun vadeli bağımlılıkları yakalamak için kullanılmıştır. Tekrarlayan katman (LSTM), evrişimli katmanla (CNN) birleştirildiğinde aynı sınıflandırma performansını, diğer metotlara göre çok daha küçük bir model kullanarak elde etmenin mümkün olduğu sonucuna varılmıştır. ConvLstm modeli ile %88.3 doğruluk oranı elde edilmiştir.

Kaynar vd. (2017), metin sayısının ve uzunluğunun artmasıyla birlikte öznelik vektöründeki artışın hesaplama zamanını artırdığı ve sınıflandırma hatalarına yol açtığı düşüncesi ile öznelik düşürme çalışması gerçekleştirmişlerdir. İlk çalışmada öznelik olarak TF-IDF değeri en yüksek olan 1000 terim ele alınmıştır. Daha sonra veri setine Temel Bileşen Analizi (TBA), Çekirdek Tabanlı Temel Bileşen Analizi (çTBA), Tekil Değer Ayrışımı (TDA), Faktör Analizi (FA), derin öğrenme tabanlı Oto Kodlayıcı (AE) ve Gürültü Giderici Oto Kodlayıcı (DAE) olmak üzere 6 farklı boyut düşürme yöntemi uygulanarak yeni veri setleri oluşturulmuştur. Elde edilen boyutu düşürülmüş veri seti ve boyutu düşürülmemiş veri seti üzerinde SVM ve ANN algoritmaları kullanılarak sonuçlar karşılaştırılmıştır. Çalışma sonucunda, öznelik düşürme yöntemlerinin duygu analizi sonuçlarını iyileştirdiği, önerilen oto kodlayıcı modellerinin ise mevcut tekniklere benzer ya da daha başarılı sonuçlar elde ettiği görülmüştür. En yüksek doğruluk oranı olan % 81.6, 390 boyutlu veri seti üzerinde DAE ile YSA yöntemlerinin birlikte kullanıldığı model ve 400 boyutlu veri seti üzerinde AE ile ANN yöntemlerinin birlikte kullanıldığı model ile elde edilmiştir.

Rane ve Kumar (2018) çalışmalarında, 6 büyük ABD Havayolu şirketi ile ilgili yazılan tweetlerden oluşan veri kümesi üzerinde yedi farklı sınıflandırma algoritması (DT, RF, SVM, KNN, LR, Gauss NB ve AdaBoost) ile pozitif, nötr ve negatif olmak üzere üçlü duygu analizi yapmışlardır. Çalışmada, öznelik seçim metodu olarak Word2vec kütüphanesinin genişletilmiş versiyonu olan Doc2vec tercih edilmiştir. Model eğitiminde sınırlı sayıda tweet kullanılması çalışma için dezavantaj oluşturmuştur. Çalışma sonucunda, AdaBoost (%84.5) ve RF (%85.6) algoritmalarının yüksek performans gösterdiği gözlemlenmiştir.

Çiftçi ve Apaydın (2018) çalışmalarında, Türk alışveriş ve film sitelerinden taranan veri kümesi üzerinde klasik makine öğrenimi algoritmaları (NB ve LR) ile derin öğrenme algoritmalarından RNN algoritmasının bir çeşidi olan LSTM yaklaşımları karşılaştırılmıştır. NB ve LR algoritmalarında öznelik seçimi için TF-IDF tercih edilirken, LSTM algoritması direkt gesim kütüphanesinin Türkçe Wikipedia makaleleri ile eğitilmesi sonucu oluşan kelime vektör modeli kelime temsilleri ile beslenmiştir. Çalışma sonucunda, LSTM algoritması NB ve LR modellerinden doğruluk, geri çağırma ve hassasiyet metrikleri bazında daha iyi performans gösterdiği görülmüştür.

Salur ve Aydın (2018) çalışmalarında, Twitter mesajları üzerinde ikili sınıflandırma (olumlu-olumsuz) işlemini, makine öğrenmesi algoritmaları (KNN, LD, DT, SVM, LR) ve derin öğrenme algoritması olan CNN ile gerçekleştirmişler ve paket boyutunun (batch size) sınıflandırmaya etkisini incelemişlerdir. Çalışma neticesinde, derin öğrenme algoritması, diğer beş makine öğrenmesi algoritmalarına kıyasla yaklaşık %10 daha yüksek başarı oranıyla veri kümesini sınıflandırmıştır.

Lee vd. (2019) çalışmalarında, IMDB veri kümesi üzerinde, yarı denetimli Derin Sinir Ağı'nı (Deep Neural Network) eğiterek model performanslarını, aynı sayıda etiketli veri ile eğitilen denetimli derin sinir ağı ile karşılaştırmışlardır. Çalışma sonucunda, yarı denetimli model verilerinin dikkatli bir şekilde kullanılmasıyla, etiketlenmemiş verilerin model performansları üzerinde olumsuz etkisi olmadan modelin eğitimine yardımcı olduğu gözlemlenmiştir.

Ray ve Chakrabarti (2019), elektronik ürün incelemeleri ile ilgili tweet verileri, film ve restoran inceleme verileri üzerinde, hedef tabanlı duygu analizi için derin öğrenme ve kural tabanlı yaklaşım (rule based approach) kullanarak duygu analiz çalışması gerçekleştirmişlerdir. Veri setleri üzerinde, önışleme metodlarından; metin sadeleştirme ve

durak kelimelerin temizlenmesi işlemleri gerçekleştirilmiştir. Çalışmada, öznelik seçme metodu olarak skip-gram ve POS tercih edilmiştir. Çalışmada önerilen yedi katmanlı CNN algoritmasının başarısını artırmak için kullanılan kural tabanlı yaklaşım ile %87 doğruluk oranı elde edilirken, POS etiketleme ve kural tabanlı yaklaşımın birlikte kullanılması ile %75 doğruluk oranı elde edilmiştir. Mevcut yöntemlerle karşılaştırıldığında, önerilen tekniğin (CNN + Kural Tabanlı) hem pozitif hem de negatif sınıflar için daha iyi sınıflandırma doğruluğu sağladığı görülmüştür.

Kamiş ve Goularas (2019), CNN ve LSTM derin öğrenme yöntemlerini kullanarak, Twitter verileri üzerinde duygu analizi çalışması gerçekleştirmişlerdir. Çalışmada, Word2vec ve GloVe öznelik seçme metodları, farklı kombinasyonlarla uygulanarak her model için puanlama değerleri belirlenmiş ve performansları açısından karşılaştırılmıştır. CNN ve LSTM ağları ile ayrı ayrı ve birleştirilerek testler gerçekleştirilmiş ve sonucunda CNN ve LSTM ağları bir araya getirildiğinde, tek başına kullanıldıklarından daha iyi performans gösterdikleri gözlemlenmiştir. Ayrıca birden çok CNN ve bir LSTM ağının kullanılması sistemin performansını artırdığı görülmüştür.

DUYGU ANALİZİNDE SÖZLÜK TABANLI YAKLAŞIM LİTERATÜR ÇALIŞMALARI

Sözlük tabanlı yaklaşım, önceden bilinen ve düzenlenmiş olan terimlerin, eş ve zıt anlamlılarından oluşan bir duygu sözlüğüne dayanmaktadır. Sözlük tabanlı yaklaşım ile duygu analizi çalışmalarına ilk olarak metinlerde aranmak istenen duygu durumları belirlenir. Belirlenen duygu durumlarını ifade eden kelimeler ve kelimelerin eş anlamlıları aranarak her bir kelime için sözlük aracılığı ile duygu durumunu ifade eden skor elde edilir. Son aşamada istatistiksel yöntemlerle metnin ifade ettiği duygu durumu tahmin edilir.

Sözlük tabanlı yaklaşım kullanılarak gerçekleştirilen güncel çalışmalara bu bölümde yer verilmektedir.

Ding vd. (2017), Çinli seyahat rezervasyon platformu olan Ly.com'dan alınan yorumlar üzerinde, Çin duygu sözlüğüne dayanan, yorumlara göre turisti otomatik puanlayan bir duygu analiz sistemi tasarlamışlardır. Toplanan verilerden, sitenin sıralama sonuçlarına göre Wuhan'daki ilk on turistik mekanın incelemesini seçmiş ve hesaplama yöntemleri ile ilk on turistik mekanı puanlanmış ve çalışma sonunda sıralama sonuçlarının Ly.com'un sıralamasıyla oldukça tutarlı olduğu sonucuna varılmıştır.

John vd. (2019), sentiment140.com'dan alınan, olumlu, olumsuz ve nötr puanları olan tweet verileri üzerinde sözlük tabanlı duygu analiz çalışması gerçekleştirmişlerdir. Veri önileme adımlarından; metin sadeleştirme, durak kelimelerin temizlenmesi, yazım denetimi, kök alma işlemleri uygulanmıştır. Çalışmada, SentiWordNet Classification, Domain Specification Classification ve Hybrid Lexicon Classification olmak üzere üç farklı metotla kelime sınıflandırma gerçekleştirilmiştir. Terimin sözlükte ifade edilen kutupluluğunun, metinde ifade edilen kutupluluktan farklı olabileceği bu nedenle metnin bağlamsal kutupluluğunun ele alınması gerektiği düşünülerek sınıflandırma işlemleri gerçekleştirilmiştir. SentiWordNet Classification'da %79.80, Domain Specification Classification'da %68.20, Hybrid Lexicon Classification ve önileme adımlarıyla yaklaşık %74.80 doğruluk elde edilmiştir. Hybrid Lexicon Classification yaklaşımının uygulanması, çalışmayı diğer çalışmalardan farklı kılmakla birlikte, uygun önileme adımlarıyla yüksek doğruluk değerlerine ulaşabileceği gösterilmiştir.

Yurtalan vd. (2019), Türkçe tweetler için sözlük tabanlı duygu analizi çalışması gerçekleştirmişlerdir. Sözlük, pozitif ve negatif kelime köklerini POS etiketleriyle etiketleyerek oluşturulan 1181 veri ögesi ve bunların polarite değerinden oluşmuştur. Türkçe tweet veri setini, kelime, kelime grubu ve deyim atasözü seviyelerinde inceleyerek, Türkçe metinlerin sözlük tabanlı analizinde, kelime grubu seviyesinde analizin en etkili yöntem olduğu ve sistem performansını geliştirdiği gözlemlenmiştir.

Ayvaz vd. (2019), Türkçe sosyal medya paylaşımlarında yapılan duygu analizi çalışmaları için yeni ve kapsamlı bir duygu kütüphanesi geliştirmek için iki farklı konuda yapılan Twitter paylaşımları üzerinden analiz çalışması gerçekleştirmişlerdir. Çalışma kapsamında, var olan kütüphanelere basit emoji karakterler ve puanlama altyapısı eklenerek genişletilmiştir. Yaz ve kış aylarında toplanan Türkçe Twitter verileri ve Survivor ile alakalı Türkçe tweetler olmak üzere iki farklı veri seti kullanılmıştır. Çalışmada ön işleme adımlarından metin sadeleştirme uygulanmıştır. Çalışma sonucunda, Twitter kullanıcılarının kış aylarında daha olumsuz paylaşımlar yaparken, bahar ve yaz aylarında daha olumlu paylaşımlar yaptıkları ve Twitter kullanıcılarının Survivor ile ilgili olumsuz paylaşımlar yaptıkları gözlemlenmiştir.

DUYGU ANALİZİNDE HİBRİT YAKLAŞIM LİTERATÜR ÇALIŞMALARI

Hibrit yaklaşım, makine öğrenimi algoritmaları ile sözlük tabanlı yaklaşımların bir arada kullanılarak gerçekleştirildiği yaklaşımlardır.

Hibrit yaklaşım kullanılarak gerçekleştirilen güncel çalışmalara bu bölümde yer verilmektedir.

Rumelli vd. (2019) çalışmalarında, Hepsiburada.com'da kullanıcıların yaptığı ürün yorumlarını ve değerlendirmeleri üzerinde makine öğrenmesi algoritmalarını ve sözlük tabanlı yaklaşımları bir arada kullanarak duygu analiz modeli geliştirmişlerdir. Çalışmada ilk adım olarak, cümle içindeki her bir kelimenin sözlükteki puan değeri ile toplama dayalı bir model geliştirilerek hesaplama yapılmıştır. Daha sonra, metinlerin polarite puanlarını baz alarak NB, RF, SVM, KNN makine öğrenmesi algoritmaları duygu analizi yapmak için eğitilmiştir. Çalışma neticesinde, duygu analizi herhangi bir insan müdahalesi uygulanmadan %73 doğruluk oranında gerçekleştirilmiştir.

Erşahin vd. (2019) çalışmalarında, sözlük tabanlı ve makine öğrenimi tabanlı yaklaşımları birlikte kullanan hibrit yaklaşım ile film, otel ve Twitter olmak üzere üç farklı veri seti üzerinde duygu analizi çalışması gerçekleştirmişlerdir. Sözlük tarafında eş anlamlı sözcüklerden oluşan bir duygu sözlüğü kullanılırken, makine öğrenmesi tarafında denetimli öğrenme sınıflandırma algoritmalarından, NB, SVM ve J48 ile çalışmalar gerçekleştirilmiştir. Özellik oluşturma algoritmasına göre yeni bir sözlük tabanlı değer üreterek bu iki yaklaşımı birleştirir ve bunu makine öğrenme sınıflandırıcılarının özellikleri ile destekler. İlk kapsamlı Türkçe duygu analizi sözlüğü, SentiTurkNet (STN), Otomatik Eş anlamlı Sözlük (ASDICT) kullanılarak genişletilerek eSTN oluşturulmuştur. Türkçe dilinde gerçekleştirilen, hibrit yaklaşım uygulanan ilk çalışma ile duygu analizi sonuçlarında diğer iki metoda göre iyileştirme sağlanmıştır.

SONUÇ

Sosyal ağlarda yapılan paylaşım sayısının artması duygu analizi ve fikir madenciliğine verilen önemi artırarak yapılan çalışmaların sayısında önemli bir artış sağlamıştır. Bu literatür tarama çalışmasında, güncel çalışmalara dikkat çekmek amacıyla son dört yıl ağırlıklı olmak üzere duygu analizi ve fikir madenciliği ile ilgili yapılmış çalışmalar ele alınmıştır. Bu alanda araştırma yapacak kişilere yol göstermek için, incelenen çalışmalar sınıflandırılarak özetlendikten sonra güncel tarihli çalışmalar başta olacak şekilde sıralanarak bir tablo halinde sunulmuştur. İncelenen çalışmalar neticesinde, duygu analizi ve fikir madenciliği konularına duyulan ilginin yıldan yıla artarak devam ettiği ve her bir çalışmanın literatürü geliştirdiği gözlemlenmiştir.

İncelenen çalışmalarda, ekseriyetle sosyal medya paylaşımları ve ürün yorumlarının yer aldığı veri setleri tercih edilmiştir. Sosyal medya özellikle Twitter paylaşımlarından oluşan veri setleri, yazım hataları, kısaltmalar, günlük konuşma dilinde yer almayan sosyal medyaya özgü ifadeler ve emojilerin yer aldığı kirli metinlerden oluşmaktadır. Bu paylaşımlar üzerinde yapılacak duygu analizi çalışmalarında, bu konu göz önüne alınmalı ve uygun doğal dil işleme yöntemleri belirlenmelidir. Farklı konularda (din, siyaset, ürün yorumu vs.) yapılan paylaşımlar üzerinde gerçekleştirilen farklı ön işleme metotları çalışmanın başarı oranını önemli ölçüde etkilemektedir.

Yapılan analiz sonucunda, duygu analizinde, makine öğrenimi yaklaşımlarının, sözlük tabanlı yaklaşımlar ve hibrit yaklaşıma göre, uygulanabilirlik açısından daha çok tercih edildiği ve başarı oranlarının daha yüksek olduğu görülmüştür. Makine öğrenimi algoritmaları içerisinde de denetimli öğrenme algoritmalarıyla gerçekleştirilen çalışmaların başarı oranlarının, denetimsiz ve yarı denetimli algoritmalara göre daha yüksek olduğu gözlemlenmiştir. Çalışmalarda tercih edilen denetimli öğrenme algoritmalarından, SVM, NB ve RF'nin sosyal medya paylaşımları üzerinden yapılan veri analizinde daha fazla kullanıldığı, SVM'nin Twitter veri kümesi üzerinde uygun ön işleme ve öznitelik seçme yöntemleriyle %90'lara ulaşan doğruluk oranı elde ettiği görülmüştür.

Makine öğrenimi yaklaşımlarında, öznitelik seçme işlemlerinin model başarısı üzerinde önemli bir etkiye sahip olduğu gözlemlenmiştir. Çalışma sonuçları incelendiğinde, n-gramların makine öğrenimi algoritmaları üzerinde oldukça etkili olduğu ve araştırmacılar tarafından tercih edildiği gözlemlenmiştir. N-gram kullanırken, N değerinin seçimi önemli bir husustur, N sayısının artması, kontrol sayısını ve buna bağlı olarak işlem gücünü artırdığı için hesaplama süresi uzar. İncelenen Türkçe çalışmalarda, N değerinin en fazla 3 alındığı görülmektedir. Aynı

algoritma üzerinde farklı öznelik seçme yöntemlerinin kullanımı ile farklı doğruluk oranları elde edilebildiği gibi farklı algoritmalar üzerinde tek bir öznelik seçme yönteminin kullanılması da model başarısını etkilemiştir.

Makine öğrenimi tekniklerinin uygulanabilmesi için gerekli olan etiketli eğitim verisi, araştırmacıları daha az miktarda etiketli veri veya etiketsiz veri ile çalışmalarını gerçekleştirebilecekleri yöntemlere yönlendirmiştir.

Son yıllarda veri miktarının artması ve donanımın gelişmesi ile denetimli, denimsiz ve yarı denetimli yöntemleri bir arada kullanabilen derin öğrenme algoritmalarına da araştırmacıların ilgisinin her geçen yıl arttığı görülmektedir. Duygu analizinde, makine öğrenimi denetimli öğrenme algoritmalarının, dilden bağımsız ve başarı oranlarının yüksek olması nedeniyle tercih edildiği fakat derin öğrenme algoritmalarının da uygun veri kümelerinde yüksek başarı oranları elde ettiği görülmüştür. Geleneksel makine öğrenimi yöntemleri yerine derin öğrenme yöntemlerinin tercih edilme nedenlerinin; işlenecek veri miktarı, kullanılacak donanım özellikleri, algoritmanın öğrenme metodolojisi, algoritmanın veri işleme süresi ve çalışma sonucunda farklı tiplerde çıktı (ses, metin, sınıflandırma, puan) üretilebilme olduğu görülmüştür. İncelenen çalışmalar içerisinde, aynı veri seti üzerinde, geleneksel makine öğrenimi algoritmaları (NB ve LR) ile derin öğrenme algoritması olan LSTM karşılaştırıldığında, LSTM'nin model başarı oranını iyileştirdiği görülmüştür.

İncelenen çalışmalar ışığında, diğer dillerde yapılan çalışmalara kıyasla Türkçe metinler üzerinde yapılan doğal dil işleme çalışmalarının yetersiz olduğu, hem Türkçe hem de diğer diller için duygu analizi çalışmalarının gelişime açık olduğu, özellikle derin öğrenme alanında yapılan duygu analizi çalışmalarının önemli araştırma konuları haline geldiği, Türkçe metinler üzerinde derin öğrenme çalışmalarına ihtiyaç duyulduğu söylenebilir.

KAYNAKLAR

- Agarwal, A., Xie, B., Vovsha, I., Rambow, O. ve Passonneau, R. (2011). Sentiment analysis of twitter data. In *Proceedings of the workshop on language in social media (LSM 2011)*, 30–38.
- Al-Hadhrani, S., Al-Fassam, N. ve Benhidour, H. (2019). Sentiment Analysis of English Tweets: A Comparative Study of Supervised and Unsupervised Approaches. *2nd International Conference on Computer Applications and Information Security (ICCAIS 2019)*, 1–5.
- Asghar, M. Z., Ullah, R., Ahmad, S., Kundi, F. M. ve Nawaz, I. U. (2014). Lexicon based approach for sentiment classification of user reviews. *Life Science Journal*, 11(10), 468–473.
- Atalay, M. ve Çelik, E. (2017). Büyük Veri Analizinde Yapay Zekâ Ve Makine Öğrenmesi Uygulamaları - Artificial Intelligence and Machine Learning Applications in Big Data Analysis. *Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 9, 155–172.
- Ayvaz, S., Yıldırım, S. ve Salman, Y. B. (2019). Türkçe Duygu Kütüphanesi Geliştirme: Sosyal Medya Verileriyle Duygu Analizi Çalışması. *European Journal of Science and Technology*, 16, 51–60.
- Baccianella, S., Esuli, A. ve Sebastiani, F. (2010). Sentiwordnet 3.0: An enhanced lexical resource for sentiment analysis and opinion mining. *Proceedings of the 7th International Conference on Language Resources and Evaluation (LREC 2010)*, 2200–2204.
- Bilgin, M. ve Şentürk, İ. F. (2019). Danışmanlı ve yarı danışmanlı öğrenme kullanarak doküman vektörleri tabanlı tweetlerin duygu analizi. *Balıkesir Üniversitesi Fen Bilim. Enstitüsü Dergisi*, 21, 822–839.
- Bojanowski, P., Grave, E., Joulin, A. ve Mikolov, T. (2017). Enriching Word Vectors with Subword Information. *Transactions of the Association for Computational Linguistics*, 5, 135–146.
- Chakraborty, K., Bag, R. ve Bhattacharyya, S. (2018). Relook into Sentiment Analysis performed on Indian Languages using Deep Learning. In *2018 Fourth International Conference on Research in Computational Intelligence and Communication Networks (ICRCICN)*, 208–213.
- Chen, Y. ve Zhang, Z. (2018). Research on text sentiment analysis based on CNNs and SVM. In *2018 13th IEEE Conference on Industrial Electronics and Applications (ICIEA)*, 2731–2734.

- Chen, C. C. ve Tseng, Y. D. (2011). Quality evaluation of product reviews using an information quality framework. *Decision Support Systems*, 50(4), 755–768.
- Cliche, M. (2017). BB twtr at SemEval-2017 Task 4: Twitter Sentiment Analysis with CNNs and LSTMs, *arXiv preprint arXiv:1704.06125*.
- Çelik, Ö. ve Aslan, A. F. (2019). Gender Prediction from Social Media Comments with Artificial Intelligence. *Sakarya University Journal of Science*, 23, 1256–1264.
- Çetin, F. S. ve Eryiğit, G. (2018). Türkçe Hedef Tabanlı Duygu Analizi İçin Alt Görevlerin İncelenmesi – Hedef Terim, Hedef Kategori Ve Duygu Sınıfı Belirleme. *Bilişim Teknolojileri Dergisi*, 11, 43–56.
- Çiftçi, B. ve Apaydın, M. S. (2018). A Deep Learning Approach to Sentiment Analysis in Turkish. In *2018 International Conference on Artificial Intelligence and Data Processing (IDAP)*, 1–5.
- Çoban, Ö. ve Özyer, G. T. (2018). Word2vec and Clustering based Twitter Sentiment Analysis. In *2018 International Conference on Artificial Intelligence and Data Processing (IDAP)*, 1–5.
- Çoban, O., Özyer, B. ve Özyer, G. T. (2015). Türkçe Twitter Mesajlarının Duygu Analizi. In *2015 23rd Signal Processing and Communications Applications Conference (SIU)*, 2388–2391.
- Dehkharghani, R., Saygin, Y., Yanikoglu, B. ve Oflazer, K. (2016). SentiTurkNet: a Turkish polarity lexicon for sentiment analysis. *Language Resources and Evaluation*, 50(3), 667–685.
- Desai, R. D. (2018). Sentiment Analysis of Twitter Data. In *2018 Second International Conference on Intelligent Computing and Control Systems (ICICCS)*, 114–117.
- Ding, Y., Li, B., Zhao, Y. ve Cheng, C. (2017). Scoring tourist attractions based on sentiment lexicon. In *2017 IEEE 2nd Advanced Information Technology, Electronic and Automation Control Conference (IAEAC)*, 1990–1993.
- El Rahman, S. A., Alotaibi, F. A. ve Alshehri, W. A. (2019). Sentiment Analysis of Twitter Data. In *2019 International Conference on Computer and Information Sciences (ICCIS)*, 1–4.
- Erşahin, B., Aktaş, Ö., Kılınç, D. ve Erşahin, M. (2019). A hybrid sentiment analysis method for Turkish. *Turkish Journal of Electrical Engineering and Computer Science*, 27, 1780–1793.
- Esuli, A. ve Sebastiani, F. (2006). Sentiwordnet: A publicly available lexical resource for opinion mining. *Proceedings of the 5th International Conference on Language Resources and Evaluation (LREC 2006)*, 417–422.
- Go, A., Bhayani, R. ve Huang, L. (2009). Twitter Sentiment Classification using Distant Supervision. *CS224N project report*, 1(12), Stanford.
- Hassan, A. ve Mahmood, A. (2017). Deep Learning approach for sentiment analysis of short texts. In *2017 3rd international conference on control, automation and robotics (ICCAR)*, 705–710.
- Hayran, A. ve Sert, M. (2017). Sentiment Analysis on Microblog Data Based on Word Embedding and Fusion Techniques. In *2017 25th Signal Processing and Communications Applications Conference (SIU)*, 1–4.
- Hu, M. ve Liu, B. (2004). Mining and Summarizing Customer Reviews. *Proceedings of the Tenth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 168–177.
- Ian, H. W., ve Eibe, F. (2005). *Data Mining: Practical Machine Learning Tools and Techniques*.
- John, A., John, A. ve Sheik, R. (2019). Context Deployed Sentiment Analysis Using Hybrid Lexicon. In *2019 1st International Conference on Innovations in Information and Communication Technology (ICIICT)*, 1–5.

- Kamiş, S. ve Goularas, D. (2019). Evaluation of Deep Learning Techniques in Sentiment Analysis from Twitter Data. In *2019 International Conference on Deep Learning and Machine Learning in Emerging Applications (Deep-ML)*, 12–17.
- Kaynar, O., Aydın, Z. ve Görmez, Y. (2017). Sentiment Analizinde Öznitelik Düşürme Yöntemlerinin Oto Kodlayıcılı Derin Öğrenme Makinaları ile Karşılaştırılması. *Bilişim Teknolojileri Dergisi*, 10(3), 319–326.
- Kaynar, O., Yıldız, M., Görmez, Y. ve Albayrak, A. (2016). Makine Öğrenmesi Yöntemleri ile Duygu Analizi. In *International Artificial Intelligence and Data Processing Symposium (IDAP'16)*, 234–241.
- Kurniawati, I. ve Pardede, H. F. (2018). Hybrid Method of Information Gain and Particle Swarm Optimization for Selection of Features of SVM-Based Sentiment Analysis. In *2018 International Conference on Information Technology Systems and Innovation (ICITSI)*, 1–5.
- Lee, V. L. S., Gan, K. H., Tan, T. P. ve Abdullah, R. (2019). Semi-supervised learning for sentiment classification using small number of labeled data. *Procedia Computer Science*, 161, 577–584.
- Liu, B. (2012). Sentiment Analysis and Opinion Mining. *Synthesis lectures on human language technologies*, 5(1), 1-167.
- Maynard, D. ve Funk A. (2011). Automatic detection of political opinions in tweets. In *Extended Semantic Web Conference*, 88–99, Springer, Berlin, Heidelberg.
- Medhat, W., Hassan, A. ve Korashy, H. (2014). Sentiment analysis algorithms and applications: A survey. *Ain Shams Engineering Journal*, 5(4), 1093–1113.
- Medhat, W., Hassan, A. ve Mohamed, H. K. (2014). Combined algorithm for data mining using association rules. *Ain Shams J. Electr. Eng.*, 1(1), 1–12.
- Mikolov, T., Chen, K., Corrado, G. ve Dean, J. (2013). Efficient estimation of word representations in vector space. *arXiv preprint arXiv:1301.3781*.
- Mikolov, T., Sutskever, I., Chen, K., Corrado, G. ve Dean, J. (2013). Distributed Representations of Words and Phrases and Their Compositionality. *arXiv preprint arXiv:1310.4546*.
- Mukwazvure, A. ve Supreethi, K. P. (2015). A hybrid approach to sentiment analysis of news comments. *2015 4th International Conference on Reliability, Infocom Technologies and Optimization (ICRITO)*, 1–6.
- Nasukawa, T., Yi J. (2003). Sentiment analysis: Capturing favorability using natural language processing. In *Proceedings of the 2nd international conference on Knowledge capture (K-CAP 2003)*, 70-77.
- Naz, S., Sharan, A. ve Malik, N. (2018). Sentiment Classification on Twitter Data Using Support Vector Machine. In *2018 IEEE/WIC/ACM International Conference on Web Intelligence (WI)*, 676–679.
- Neviarouskaya, A., Prendinger, H. ve Ishizuka, M. (2011). Affect Analysis Model: Novel rule-based approach to affect sensing from text. *Natural Language Engineering*, 17(1), 95–135.
- Onan, A. (2017). “Twitter Mesajları Üzerinde Makine Öğrenmesi Yöntemlerine Dayalı Duygu Analizi. *Yönetim Bilişim Sistemleri Dergisi*, 3(2), 1–14.
- Osmanoğlu, U. Ö., Atak, O. N., Çağlar, K., Kayhan, H. ve Can, T. (2020). Sentiment Analysis for Distance Education Course Materials: A Machine Learning Approach. *Journal of Educational Technology and Online Learning*, 3, 31–48.
- Özsert, C. M. ve Özgür, A. (2013). Word Polarity Detection Using a Multilingual Approach. In *International Conference on Intelligent Text Processing and Computational Linguistics*, 75–82, Springer, Berlin, Heidelberg.
- Özyurt, B. ve Akçayol, M. A. (2018). Fikir Madenciliği ve Duygu Analizi, Yaklaşımlar, Yöntemler Üzerine Bir Araştırma. *Selçuk Üniversitesi Mühendislik, Bilim ve Teknoloji Dergisi*, 6(4), 668-693.

- Pang, B., Lee, L. ve Vaithyanathan, S. (2002). Thumbs up? Sentiment classification using machine learning techniques. *Proceedings of the 2002 Conference on Empirical Methods in Natural Language Processing*, Philadelphia.
- Parlar, T., Saraç, E. ve Özel, S. A. (2017). Comparison of Feature Selection Methods for Sentiment Analysis on Turkish Twitter data. In *2017 25th Signal Processing and Communications Applications Conference (SIU)*, 1–4.
- Pennington, J., Socher, R ve Manning, C. D. (2014). GloVe: Global Vectors for Word Representation. In *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 1532–1543.
- Pervan, N. ve Keleş, H. Y. (2017). Sentiment Analysis Using A Random Forest Classifier On Turkish Web Comments. *Communications Faculty of Sciences University of Ankara Series A2-A3 Physical Sciences and Engineering*, 59(2), 69–79.
- Rane, A. ve Kumar, A. (2018). Sentiment Classification System of Twitter Data for US Airline Service Analysis. In *2018 IEEE 42nd Annual Computer Software and Applications Conference (COMPSAC)*, 1, 769–773.
- Ray, P. ve Chakrabarti, A. (2019). A Mixed approach of Deep Learning method and Rule-Based method to improve Aspect Level Sentiment Analysis. *Applied Computing and Informatics*.
- Rumelli, M., Akkuş, D., Kart, Ö. ve Işık, Z. (2019). Sentiment Analysis in Turkish Text with Machine Learning Algorithms. In *2019 Innovations in Intelligent Systems and Applications Conference (ASYU)*, 1–5.
- Salur, M. U. ve Aydın, I. (2018). Sentiment classification based on deep learning. In *2018 26th Signal Processing and Communications Applications Conference (SIU)*, 1–4.
- Şeker, A., Diri, B. ve Balık, H. H. (2017). Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme. *Gazi Mühendislik Bilimleri Dergisi*, 3(3), 47–64.
- Taboada, M., Brooke, J., Tofiloski, M., Voll, K. ve Stede, M. (2011). Lexicon-Based methods for sentiment analysis. *Computational Linguistics*, 37(2), 267-307.
- Turkmen, A. C. ve Cemgil, A. T. (2014). Mikroblog verilerinden politik ilgililik ve eğilim tahmini. In *2014 IEEE 22nd Signal Processing and Communications Applications Conference*, 1327–1330.
- Turney, P. D. (2002). Thumbs up or thumbs down? Semantic orientation applied to unsupervised classification of reviews. *ACL '02 Proc. 40th Annu. Meet. Assoc. Comput. Linguistics*, 417–424.
- Yüksel, A. S. ve Tan, F. G. (2018). Metin Madenciliği Teknikleri İle Sosyal Ağlarda Bilgi Keşfi. *Mühendislik Bilimleri ve Tasarım Dergisi*, 6(2), 324–333.
- Yurtalan, G., Koyuncu, M. ve Turhan, Ç. (2019). A polarity calculation approach for lexicon-based Turkish sentiment analysis. *Turkish Journal of Electrical Engineering and Computer Science*, 27, 1325–1339.